

基于隐语义模型的物联网资源发现算法

单涛^{1,2}, 钱琪杰^{3,4}, 景慎旗^{1,2}, 叶继元¹, 郭永安^{3,4}, 刘云²

(1. 南京大学信息管理学院, 南京 210023; 2. 江苏省人民医院, 南京 210096; 3. 南京邮电大学通信与信息工程学院, 南京 210003; 4. 教育部泛在网络健康服务系统工程研究中心, 南京 210003)

摘要: 由于物联网中服务数量的海量性、设备状态的动态变化性等特点, 传统的互联网中基于关键词的“被动式”语义服务搜索技术将不再适用于物联网环境, 如何利用并分析用户和设备之间大量的交互信息来给用户推荐与之最相关的设备资源是物联网中资源发现算法的关键。为此, 首先给出一种基于超图理论的物联网用户-设备交互的表示模型并配以对应的表示矩阵, 基于该模型提出了物联网业务场景中的资源推荐问题, 并将该问题转换成基于矩阵分解的相关程度预测问题, 最后引入最优化理论中的交替最小二乘法 (Alternating least squares, ALS) 来求解矩阵的最优化分解问题, 进而提出一种基于隐语义模型的资源推荐算法, 并与传统推荐系统中基于物品的协同过滤算法 (ItemCF) 在均方根误差 (Root mean square error, RMSE) 和平均绝对误差 (Mean absolute error, MAE) 等方面作对比, 实验结果证明了本文所提出的推荐算法的有效性。

关键词: 隐语义模型; 物联网; 资源发现; 信息交互; 资源推荐算法

中图分类号: TP18 **文献标志码:** A

IoT Resource Discovery Algorithm Based on Latent Factor Model

SHAN Tao^{1,2}, QIAN Qijie^{3,4}, JING Shenqi^{1,2}, YE Jiyuan¹, GUO Yong'an^{3,4}, LIU Yun²

(1. School of Information Management, Nanjing University, Nanjing 210023, China; 2. Jiangsu Province Hospital, Nanjing 210096, China; 3. College of Telecommunications & Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; 4. Engineering Research Center of Health Service System Based on Ubiquitous Wireless Networks, Ministry of Education, Nanjing 210003, China)

Abstract: The traditional keyword-based “passive” semantic service search technology in the Internet will no longer be applicable to the internet of things (IoT) environment due to the sharp growth of sensors as well as the frequent change of device state. How to utilize and analyze a large amount of interactive information between users and devices to recommend the most relevant equipment resources according to users’ preference is the key of resource discovery algorithm in IoT. A representation model of user-device interaction based on hypergraph theory was presented and matched with corresponding representation matrix. Based on this model, the resource recommendation problem which can be transformed into a correlation degree prediction problem based on matrix decomposition was formulated. Then the alternating least squares (ALS) method in optimization theory was introduced here to tackle this optimal

基金项目: 国家重点研发计划 (2018YFC1314900); 江苏省前沿引领技术基础研究专项 (BK20202001); 江苏省工业和信息化产业转型升级专项资金 (苏财工贸[2021]92号)。

收稿日期: 2022-04-12; **修订日期:** 2022-05-12

decomposition problem. Finally, the IoT resource recommendation algorithm based on latent factor model was proposed. The simulation proved that the proposed approach outperformed item-based collaborative filtering (ItemCF) algorithm in terms of root mean square error (RMSE) and mean absolute error (MAE).

Key words: latent factor model; internet of things (IoT); resource discovery; information interaction; resource recommendation algorithm

引言

物联网是实现物物相连的网络,它是连接物理世界和数字世界的桥梁。物联网通过传感器、全球定位和射频识别等信息传感技术,按照规定的数据和通信协议,把物理世界中的设备资源与应用层的用户业务相连接,进行信息交换和通信,将互联网扩展到物理世界中,从而实现感知层设备资源的智能化控制、监控和管理^[1]。通过物联网的连接,网络中可被使用的数据由传统互联网中的网页数据扩展到涵盖了网页、人和物体等多维信息的数据,这些数据通过互联网、电信网及无线网络进行联接、控制和管理^[2]。随着网络规模的不断扩大,物联网中的数据、设备和服务的数量也呈现出海量式的增长趋势,而且感知层的设备往往处于不断变化的状态,所以传统的互联网中基于关键词的“被动式”语义服务搜索技术将不再适用于物联网环境,物联网服务搜索的对象由传统互联网中的文档、网页等延伸到大数据量、大信息量、关系复杂的物理世界,这将会导致物联网搜索问题变得更加复杂。

面对不断增加的传感器及其生成的海量数据,只有通过采用智能的物联网资源发现算法等先进技术,才能充分挖掘并激活这些数据的潜在价值^[3]。为此,本文提出一种基于隐语义模型的“主动式”物联网资源发现算法,即根据用户对终端资源历史行为的数据、终端设备之间的互相关性以及用户之间的相关性等数据,为用户推送与之最相关的终端资源以提高物联网中服务发现的效率。而有效的资源推荐算法是实现物联网业务场景中的“主动式”资源发现的关键,一方面,资源推荐算法能够根据用户的行为和喜好推荐用户可能会用的终端设备;另一方面,在特定的应用场景下,推荐算法能够优化物联网资源发现的时间成本,进而为用户提供高效的资源搜索服务。

由于应用场景、资源等配置情况的不同,物联网服务和传统的 Web 服务相比有着不同的特点^[4],例如异构性和服务的执行受到设备资源条件的限制等。正是由于这些不同的特点,使得物联网业务环境下的资源推荐算法比传统的推荐系统更具有资源上下文相关性(例如设备的地理位置不同、应用场景存在差别等)和设备状态的动态变化性。因此,物联网中的资源推荐算法的设计面临着以下几个方面的挑战:

(1) 实体间关系的多样性。物联网中的实体(终端设备、用户等)、数据、信息和领域知识之间的异构关系和相互依赖程度正呈指数式增长的趋势,从而导致了网络的复杂性和资源检索的低效率性。实体间关系的多样性和复杂性是物联网资源推荐算法设计中面临的一大挑战,若不能正确辨别出这些实体间的隐含关系,将会大大降低物联网资源推荐算法的准确性。

(2) 设备节点的动态变化性。物联网环境中,传感器通常被集成于动态的物理实体之内,随之而来的是一个新的挑战,这些传感器节点随着物体移动,注册信息的实时更新变得更加复杂。同时,绝大多数物理设备处于资源有限且不断变化的环境中,其节点状态(如工作条件和参数)频繁变动。这种动态性对物联网资源发现算法的实时响应能力提出了更高的要求,需要算法能够迅速适应环境的变化,确保信息的准确性和可靠性。

(3) 资源搜索的多元性。物联网资源搜索的对象不再是传统互联网中单纯的网页文档,而是由用户、终端设备、物理环境有机结合的复合内容。因此,物联网业务场景中的资源搜索需要通过多个维度

获得搜索的数据,只有同时利用各种物联网终端设备实时感知用户的需求,进而对获取到的各类搜索数据进行深度融合与分析,才能为用户推荐与之最相关的设备列表。

为了应对上述的这些挑战,本文首先给出一种基于超图理论的物联网用户-设备交互的表示模型,并基于该模型设计对应的数学表示矩阵,进而提出了物联网业务场景中的资源推荐问题,并将该问题转换成基于矩阵分解的相关程度预测问题,引入最优化理论中的交替最小二乘法(Alternating least squares, ALS)来求解矩阵的最优化分解问题,最后提出一种基于隐语义模型的资源推荐算法,并与传统推荐系统中基于物品的协同过滤算法^[5]在均方根误差(Root mean square error, RMSE)和平均绝对误差(Mean absolute error, MAE)等方面做对比,基于机器学习库 Mahout^[6]的实验结果证明本文所提出的推荐算法的有效性。

1 相关工作

为业务层的用户提供准确高效的资源发现算法是物联网服务智慧化过程中的关键一步。然而,有效地搜索终端设备要比传统互联网中网页文档的查找过程复杂得多,因为感知层的传感器等设备与其所处的上下文信息(例如位置和时间等)紧密地关联,并且设备的状态是动态变化的,此外,与网页文档中的可读文本不同,感知层海量的异构终端设备往往不具有容易检索的属性。

在物联网资源发现方面,Teixeira等^[7]提出采用概率发现的方法来搜索满足用户业务请求的近似服务集和,以加速物联网中的资源发现并减小计算资源的消耗。他们认为,随着物联网服务数量的增加,即使执行一个简单的服务发现操作,其资源消耗都有可能超过设备所具有的资源量,但基于概率发现的方法需要大量的训练数据来提高准确度,且存在“冷启动”的问题。SenseWeb^[8]设计了基于元数据的传感器搜索框架,传感器的位置等信息存储在元数据中,搜索引擎通过关键词查询元数据以寻找对应的终端设备集合,但该框架需要提前设计复杂的服务描述文档以支持不同情境下的业务发现,类似于这类基于关键词的搜索引擎还有 Microsearch^[9]和 Snoogle^[10]。中间件系统 GSN(Global sensor networks)^[11]则采用基于容器的服务架构来管理各个虚拟传感器,虚拟传感器与感知层的实际传感器存在映射关系,并且利用元数据的标注方式描述传感器信息。用户可以指定设备标识号或者提供描述传感器的元数据作为搜索的关键词来查找和使用对应的设备,但这种搜索机制并不支持基于传感器状态的查询,当用户查询当前带有指定输出值的传感器设备时,需要与所有的可搜寻传感器进行通信,是不能适用于大规模的泛在网络的。语义传感网络本体模型(Semantic sensor network ontology, SSNO)^[12]采用多维度的基于文本形式的标签(传感器的位置、测量单位、绑定设备等)来描述传感器,这些标签数据通常由传感器的部署人员去配置,其他的用户需要基于不同标签的关键词去搜索相应的传感器设备,但这种模式存在的问题就是用户需要具有先验知识,即用户需要提供关于传感器不同维度的标签元素的正确描述符(例如 RDF, Resource description framework)^[13]才能保证资源发现的准确性,而一般的用户是不具备这些条件的。

然而,上述的这些解决方案并没有充分挖掘用户与设备之间丰富的历史交互数据,这些数据中通常隐含了不同设备之间的隐式关系,例如,如果用户对某些设备的使用模式相似,这可能暗示了这些设备之间存在较高的相似度。Ostermaier等^[14]提出了一种用于物联网的实时搜索引擎,它允许用户搜索具有某些属性的物理世界的实体,他们将网页与包含多种传感器设备的物理实体相关联,同时用附加的结构化元数据来描述传感器。这种方法充分利用了用户和设备交互的历史数据的价值,但忽略了设备上下文环境之间的关系。Yao等^[15]通过将环境上下文信息映射到单独的图(Graph),再利用图中的

顶点之间边的权重值来反映不同设备之间的相关程度,但采用图的描述结构并不能全面捕捉到异构设备之间复杂的关系,在将设备之间多维度信息压缩到图的过程中必然会带来部分有用信息的损失。

在物联网业务场景中,如何充分挖掘用户和设备之间海量的交互信息,进而给用户推荐与之最相关的设备资源是物联网中资源发现算法的关键。而又由于物联网中设备数量的海量性、状态的动态变化性等特点,上述相关工作中基于关键词的“被动式”语义服务搜索技术将不再适用于物联网环境,为此,本文提出一种基于隐语义模型的资源推荐算法,通过分析用户与传感器设备之间的交互数据(使用频数、时间、位置等),提取用户与用户、设备与设备之间的隐含关系来为用户推荐与之最相关的设备列表,最终达到提高物联网资源发现效率的目标。

2 基于隐语义模型的物联网资源发现算法

物联网中的设备和终端通常是面向功能的,具有相似或相同功能的设备之间往往存在很强的互相关性^[16]。具有不同功能的设备所面向的人群也不同,而一对出现的设备集则表明这些设备在功能上存在相似性或者互补性^[17],例如打印机和电脑、水龙头和切菜板等,即设备之间的互相关性会反映在具体的使用场景和模式下,充分挖掘不同的设备之间这种潜在相关性会给资源推荐带来参考价值。

而物联网业务场景下的资源发现问题则应该着重考虑如何利用并分析用户和设备之间大量的历史交互信息以得到不同设备之间的互相关矩阵,再根据不同用户的偏好为用户生成对应的设备推荐列表,最后基于这种“主动式”的资源发现方法来提高物联网中资源搜索的效率。为方便问题分析,此处用式(1)中的四元组的形式来描述每一条用户对设备的行为记录,其中 $U = \{u_1, u_2, \dots, u_n\}$, $D = \{d_1, d_2, \dots, d_l\}$, $L = \{l_1, l_2, \dots, l_m\}$, $T = \{t_1, t_2, \dots, t_m\}$ 分别表示用户集合、设备集合、位置集合以及时间戳集合。每一条使用记录可用 $m \in M = \{m_1, m_2, \dots, m_M\}$ 来表示。

$$m \in M = \{m_1, m_2, \dots, m_M\} = \{ \langle u, d, l, t \rangle \mid u \in U \wedge d \in D \wedge l \in L \wedge t \in T \} \quad (1)$$

利用上述的使用记录可以分析得到用户对不同设备的使用频数,可表示为成对的“用户-设备”元组的形式,即 (i, j) , $\forall i \in U, \forall j \in D$, 而设备的使用频数 $r_{i,j}$ 与 (i, j) 相对应,映射关系为

$$\{ (i, j) \rightarrow r_{i,j} \} \quad i \in U, j \in D \quad (2)$$

本文旨在通过分析已知的 $r_{i,j}$ 来计算设备之间隐含的相关性,并根据用户的历史偏好预测其对未知设备的感兴趣程度 $\hat{r}_{i,j}$, 利用排序函数生成用户的设备推荐列表。该问题的求解过程如图1所示,此处把求解过程分解为以下两个步骤:

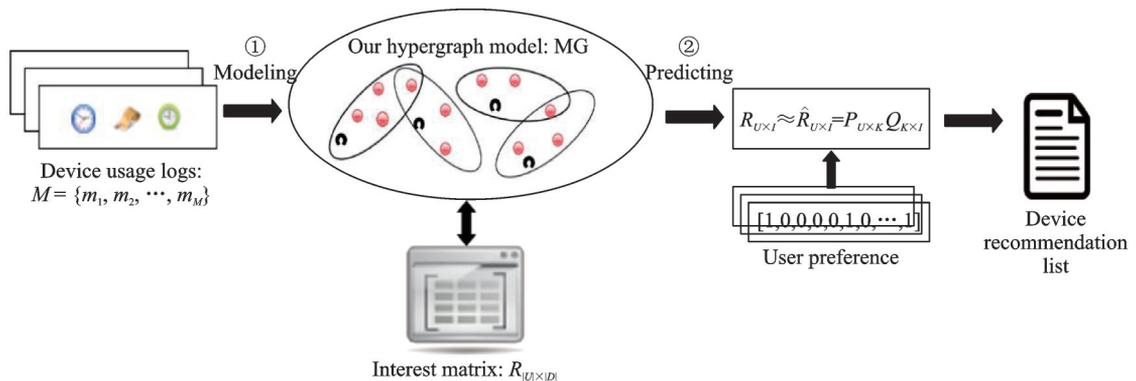


图1 本文所提出的物联网资源发现算法流程示意图

Fig.1 Flow diagram of IoT resource discovery algorithm proposed in this paper

(1)基于超图理论的数学建模过程。由于用户与设备、设备与设备以及用户与用户之间关系的复杂性与综合性,此处通过分析用户对设备的行为记录 $M = \{m_1, m_2, \dots, m_M\}$,给出一种基于超图理论^[18]的物联网用户-设备交互的表示模型MG并配以对应的表示矩阵 $R_{|U| \times |D|}$,使用超图模型可以有效地表示异构实体之间的复杂关系,最后基于该模型提出了物联网业务场景中的资源推荐问题。

(2)基于隐语义模型的资源推荐过程。得到矩阵 $R_{|U| \times |D|}$ 后,将资源推荐问题转换成基于矩阵分解的相关性预测问题,引入最优化理论中的ALS来求解矩阵的最优化分解问题,进而提出一种基于隐语义模型的资源推荐算法。

2.1 基于超图理论的数学建模

在图论中,超图(Hypergraph)是一种广义的图,超图 $H(V, E)$ 由节点集合 V 和超边(Hyperedge)的集合 E 构成,其中,每一个超边 e 都是 V 的一个非空集合,一般 e 所包含的节点数就表示其度数,记为 $|e|$ (大于等于2)。超图的特点是一条超边可以连接多个节点,超边的权重值 ϵ 反映了节点之间的相关程度,通过超图可以探索各个节点之间复杂的潜在相关性。超图理论已经在推荐系统^[19]和多标签分类系统^[20]中得到了广泛应用。

此处,为了利用超图模型来表示用户与设备、设备与设备以及用户与用户之间的复杂的高阶关系,令节点集合 $V = U \cup D$,同时规定每一条超边中只能含有一个用户节点和多个设备节点,这样的好处就是可以表示一个用户使用多个设备的情况。因为未规定一条超边必须包含几个节点,超图的描述比较自由化;而简单图则达不到这样的效果,超图与简单图的表示效果对比举例如图2所示,可以看出,简单图中的一条边只能连接一个用户和一个设备,而不能表示一个用户同时使用多个设备的情况,进而导致其不能清晰地反映多个设备之间的相关程度,如 $\langle u_1, d_1 \rangle$ 和 $\langle u_1, d_2 \rangle$;而利用超图模型进行表示就能克服上述缺点,同时能反映出不同用户使用设备的交集情况。

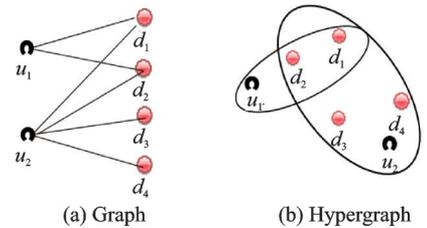


图2 超图与简单图对比

Fig.2 Comparison of hypergraphs and simple graphs

同时,定义与超图相对应的关联矩阵 $R_{|U| \times |D|}$ 以反映用户对不同设备的使用强度与偏好程度,规定矩阵元素 $r_{i,j}, \forall i \in U, j \in D$ 的值等于用户 i 使用设备 j 的频数,这样最终会得到一个“用户-设备”的稀疏矩阵,而资源推荐算法的最终目的则是利用矩阵的已知项 $r_{i,j}$ 来预测未知项 $\hat{r}_{i,j}, \hat{r}_{i,j}$ 表示用户 i' 对未知设备 j' 的兴趣程度,最后取 $\hat{r}_{i,j}, \forall i' \in U, j' \in D$ 中较大的一组值对应设备集推荐给用户以完成物联网业务场景中的资源推荐过程,最终实现物联网资源发现的效率以及准确度的提高。

2.2 基于隐语义模型的资源推荐

隐语义模型(Latent factor model, LFM)^[21]的核心思想就是通过隐含特征来联系用户和终端设备,该方法通常用于基于矩阵分解的推荐系统中,即将用户对终端设备的依赖程度矩阵(评分矩阵) $R_{U \times I}$ 分解为两个矩阵:一个是用户对终端隐含特征的偏好矩阵 $P_{U \times K}$,另一个是终端所包含的隐含特征的矩阵 $Q_{K \times I}$,3个矩阵中, U 代表用户的数量, K 代表隐含特征的个数, I 代表终端设备的数量。分解过程为

$$R_{U \times I} \approx \hat{R}_{U \times I} = P_{U \times K} Q_{K \times I} \tag{3}$$

对应的矩阵分解示意如图3所示。

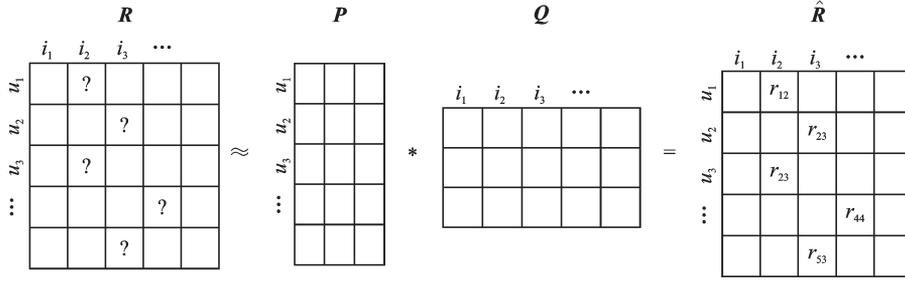


图3 基于隐语义模型的矩阵分解示意图

Fig.3 Schematic diagram of matrix decomposition based on LFM

在这个矩阵分解过程中,原评分矩阵中的缺失项(?)得到了填充,换言之,可以基于这个填充的评分项来给用户推荐与之最相关的但用户之前未使用过的终端设备,进而提高物联网服务发现的效率。可利用式(4)来预测用户 u 对未使用的终端 i 的依赖程度。

$$\text{preference}(u, i) = \hat{r}_{u,i} = \mathbf{p}_u^T \mathbf{q}_i = \sum_{k=1}^K p_{u,k} q_{k,i} \quad (4)$$

式中: $p_{u,k}$ 表示用户 u 和第 k 个隐含特征的偏好程度,而 $q_{k,i}$ 则度量了终端 i 和第 k 个隐含特征的相关程度,推荐算法的准确程度则取决于如何计算两个参数矩阵,即 $\mathbf{P}_{U \times K}$ 和 $\mathbf{Q}_{K \times I}$ 。

本文所提出的物联网业务场景中基于ALS的隐语义模型推荐算法(LFM-ALS)的具体流程如图4所示。

要计算矩阵参数 $\mathbf{P}_{U \times K}$ 和 $\mathbf{Q}_{K \times I}$,就需要一个训练集,对于每个用户 u ,训练集里都包含了其依赖程度较大和依赖程度较小的终端设备,通过学习这个数据集,就可以获得上述模型参数。为了衡量预测的精度,定义损失函数为

$$L(\mathbf{P}, \mathbf{Q}) = (\mathbf{R}_{U \times I} - \hat{\mathbf{R}}_{U \times I})^2 = \sum_{(u,i) \in T} (r_{u,i} - \hat{r}_{u,i})^2 = \sum_{(u,i) \in T} \left[r_{u,i} - \sum_{k=1}^K p_{u,k} q_{k,i} \right]^2 + \lambda (\|\mathbf{p}_u\|^2 + \|\mathbf{q}_i\|^2) \quad (5)$$

式中: $\lambda (\|\mathbf{p}_u\|^2 + \|\mathbf{q}_i\|^2)$ 为用来防止过拟合的正则化项,此处采用的是L2正则化公式, λ 的最佳取值项通常根据具体的实验场景反复试验而得。

由式(5)可知,基于隐语义模型的物联网资源推荐问题就转化成了一个单目标优化问题,即如何使 $L(\mathbf{P}, \mathbf{Q})$ 最小化。由于变量 \mathbf{p}_u 和 \mathbf{q}_i 耦合在一起,求解过程将会变得很复杂,此处引入最优化理论中的ALS^[22],先固定 $\mathbf{Q}_{K \times I}$,利用求导置零法求解 $\mathbf{P}_{U \times K}$,如式(6)所示;然后固定 $\mathbf{P}_{U \times K}$,再利用求导置零法求解 $\mathbf{Q}_{K \times I}$,如式(7)所示。如此交替往复直至收敛。

$$\frac{\partial L(\mathbf{P}, \mathbf{Q})}{\partial \mathbf{Q}} = \frac{\partial (\mathbf{R}_{U \times I} - \hat{\mathbf{R}}_{U \times I})^2}{\partial \mathbf{Q}} = 0 \rightarrow \mathbf{P}_{U \times K} \quad (6)$$

$$\frac{\partial L(\mathbf{P}, \mathbf{Q})}{\partial \mathbf{P}} = \frac{\partial (\mathbf{R}_{U \times I} - \hat{\mathbf{R}}_{U \times I})^2}{\partial \mathbf{P}} = 0 \rightarrow \mathbf{Q}_{K \times I} \quad (7)$$

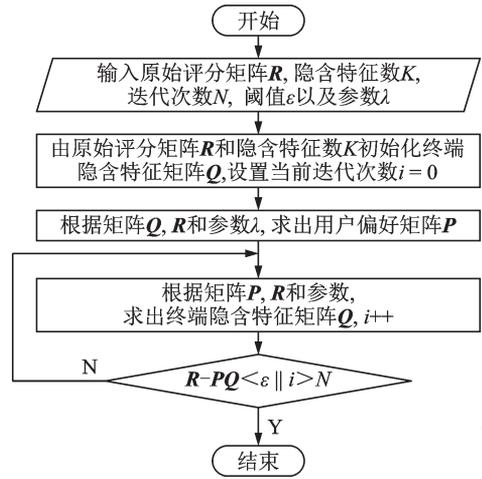


图4 LFM-ALS流程示意图

Fig.4 Flow diagram of LFM-ALS

根据最小二乘法的求解结论可得 p_u 和 q_i 的求解公式为^[23]

$$p_u = (QQ^T + \lambda E)^{-1} Q r_u \tag{8}$$

$$q_i = (P^T P + \lambda E)^{-1} P^T r_i \tag{9}$$

式中: $r_u (1 \times I)$ 为 $R_{U \times I}$ 的第 u 行, $r_i (U \times 1)$ 为 R 的第 i 列, E 为单位矩阵。

3 实验结果

3.1 实验环境设置

由于物联网资源推荐仍然是相对较新的领域,目前很难找到大规模的公开测试数据集。为此,本文基于开源项目 Kaa Project^[24] 搭建物联网资源管理平台。参考文献[25]中设置的实验环境设置,在平台之上设置几种典型的应用场景,例如办公室、厨房、卧室和客厅等,大约有 100 个传感器和终端设备接入到资源管理平台,例如打印机、电脑、冰箱、饮水机、温湿度传感器和光照传感器等,其中每个设备在平台都有对应的虚拟终端,虚拟终端向上为应用程序提供 RESTful 形式的 Web 服务调用接口;向下通过 SDK 与感知层的传感器设备进行通信,实时接收传感器的回传数据。平台支持不同物联网硬件操作系统的 SDK 生成,例如 Linux、Android、Raspberry 等。同时云平台内嵌 MongoDB 数据库,用于记录用户的历史使用数据,管理员可通过登录后台系统实时查看。

上述物联网资源管理平台的主要设计结构如图 5 所示,该体系结构是一个可实现跨行业、跨平台的资源信息共享及互联互通的服务体系架构,具体包括以下几个部分:异构终端集群环境、物联网泛在异构网络、基于 Kaa 内核的终端控制系统 (Ubuntu, 部署在 Tencent Cloud 服务器)、服务解析与管理系统 (Windows, 部署在 Alibaba Cloud 服务器) 以及各行业应用系统。该平台的核心特点在于利用 Kaa 良好的跨平台和跨网络特性,以泛在异构网络为桥梁实现对异构终端集群的管理,接收感知层反馈的数据,并依据应用层的服务请求构造虚拟终端。

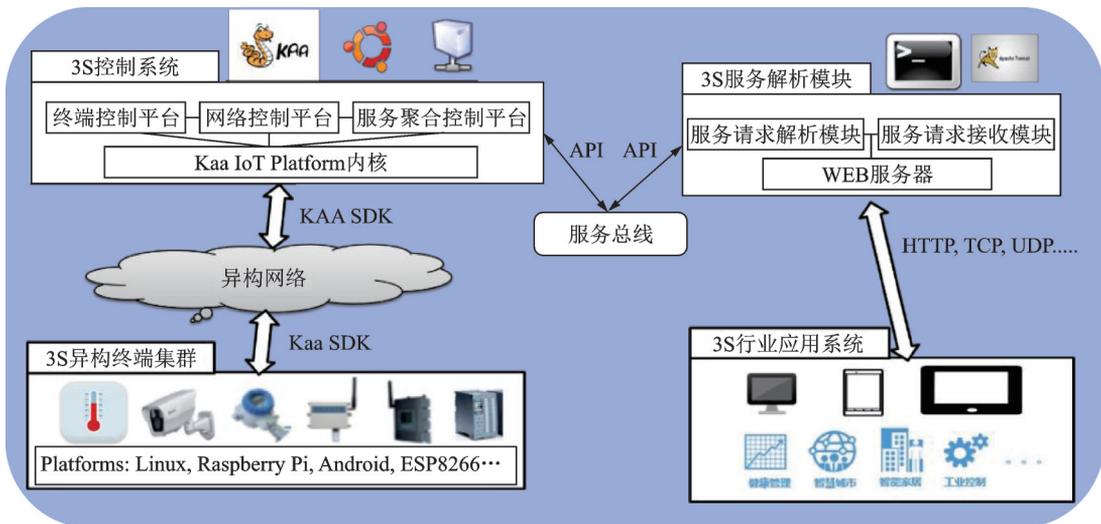


图 5 物联网资源管理平台的主要设计结构

Fig.5 Main design structure of IoT resource management platform

3.2 实验结果分析

通过采集研究室 60 位参与者大约 5 个月的历史使用数据作为实验的数据集,其中记录了 99 821 条用户与设备的交互记录。为了检验预测算法的准确度,将本文提出的 LFM-ALS 算法与传统推荐系统中基于物品的协同过滤算法(ItemCF)^[5]在 MAE^[25]和 RMSE^[26]等方面做对比。MAE 和 RMSE 的定义分别为

$$\text{MAE} = \frac{\sum_{(u,i) \in T} |r_{u,i} - \hat{r}_{u,i}|}{|T|} \quad (10)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{(u,i) \in T} (r_{u,i} - \hat{r}_{u,i})^2}{|T|}} \quad (11)$$

式中: $|T|$ 表示测试集中记录的数量, $r_{u,i}$ 代表用户 u 与设备 i 的相关性值,文中有时也称评分值,而 $\hat{r}_{u,i}$ 则表示相应的预测值。MAE 是绝对误差的平均值,其能更好地反映预测值误差的实际情况;RMSE 是指参数估计值与参数真值之差平方的期望值,RMSE 可以评价数据的变化程度,值越小,说明预测模型描述实验数据具有更好的精确度。

基于物品的协同过滤算法(ItemCF)^[5]中,存在多种计算物品相似度的方法,本文主要基于 Jaccard 和余弦相似度两种方式计算物品(设备)相似度,其对应的计算公式分别为

$$w_{ij} = \frac{|N(i) \cap N(j)|}{|N(i)|} \quad (12)$$

$$w_{ij} = \frac{|N(i) \cap N(j)|}{\sqrt{|N(i)||N(j)|}} \quad (13)$$

式中: $N(i)$ 表示喜欢物品 i 的用户数, $|N(i) \cap N(j)|$ 表示同时喜欢物品 i 和物品 j 的用户数,计算结果 w_{ij} 表示物品 i 和物品 j 的相似程度。

得到了物品(设备)的相似度之后,基于物品的协同过滤算法(ItemCF)则通过式(14)计算用户 u 与物品 j 的相关性程度。

$$p_{uj} = \sum_{i \in S(j,k) \cap N(u)} w_{ij} r_{ui} \quad (14)$$

式中: $N(u)$ 表示用户喜欢的物品集合, $S(j,k)$ 表示与物品 j 最相似的 k 个物品的集合, w_{ij} 表示物品 i 和物品 j 的相似程度, r_{ui} 表示用户 u 与物品 i 的相关性程度。

MAE 的结果对比如图 6 所示。可以看出,随着训练数据集增大,3 种算法的平均绝对误差都在减小;在训练集较小(10%~50%)的情况下,基于物品的协同过滤算法(ItemCF Based on Cosine)具有较高的预测精度;在训练集大小占数据总量的 60%~70% 时,本文所提出的基于 LFM-ALS 算法和基于物品的协同过滤算法(ItemCF Based on Cosine)性能相近;在训练集较大(90%)的情况下,LFM-ALS 算法的优势逐渐变得明显,这是因为隐语义模型需要分析大量的历史数据来获取隐含特征(一个是用用户对终端隐含特征的偏好矩阵 $P_{U \times K}$,另一个是终端所包含的隐含特征的矩阵 $Q_{K \times I}$)来联系用户和终端设备的特点造成的,较小数据集通常会影响到 LFM-ALS 算法的预测精度。

RMSE 的结果对比如图 7 所示。可以看出,对比结果是和上述 MAE 的对比结论一致的,因为 MAE

和RMSE都是衡量推荐算法预测精度的参考值,二者的区别在于计算方式不同;Shehadeh等^[26]则认为RMSE加大了对预测误差项的惩罚(平方项的惩罚),因而对系统的评测更加苛刻。Gabor等^[27]研究发现:如果评分系统是基于整数建立的(即用户给的评分都是整数),那么将预测结果取整则会降低MAE的误差。

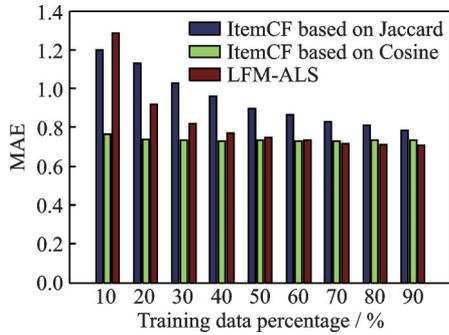


图6 MAE结果对比

Fig.6 Comparison of MAE results

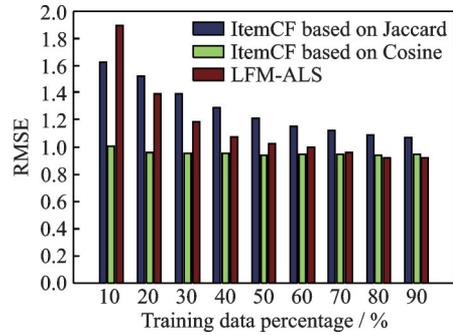


图7 RMSE结果对比

Fig.7 Comparison of RMSE results

MAE-Time对比如图8所示。由图8可知,随着LFM-ALS算法中迭代次数 N 的增加,MAE呈总体下降的趋势,但由于迭代次数的增加同时会使算法消耗更多的计算资源和时间成本。同样地,随着迭代次数 N 的增加,RMSE呈总体下降的趋势,而预测精度提高的代价则是时间成本的增加,RMSE-Time的对比如图9所示。可以发现,RMSE随迭代次数的变化波动相比MAE较大,这是和前述的RMSE加大了对预测误差项的惩罚有关系的。文献[22]研究表明,当迭代次数 N 增加到一定程度之后,MAE和RMSE的值逐步趋于稳定。综合图8和图9可以发现,该数据集的最佳迭代次数为20~25。

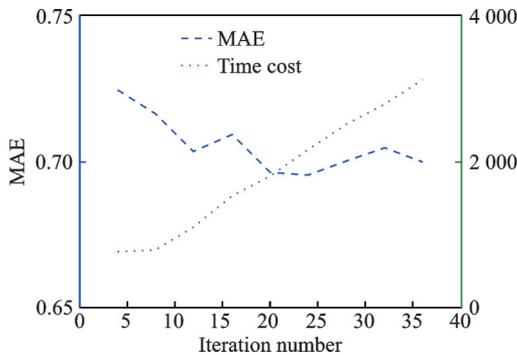


图8 MAE-Time对比

Fig.8 Comparison of MAE-Time-Iteration results

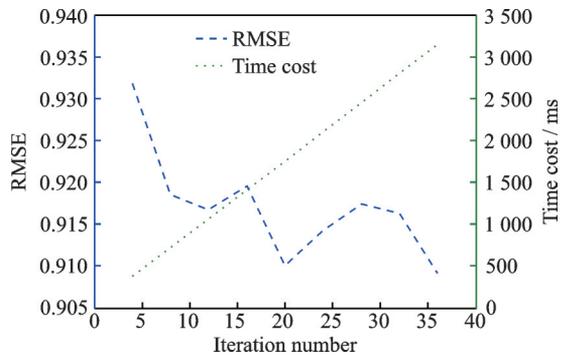


图9 RMSE-Time对比

Fig.9 Comparison of RMSE-Time-Iteration results

4 结束语

随着无线通信、嵌入式等技术的发展,接入到物联网中的异构设备越来越多。面对海量的传感器设备和物联网应用,基于关键词的“被动式”语义服务搜索技术将不再适用于复杂的物联网业务场景。为了提高物联网中资源发现的效率,本文提出了一种基于隐语义模型的物联网资源发现算法 LFM-ALS,旨在通过挖掘用户和设备之间大量的交互信息来给用户推荐与之最相关的设备资源。首先基于

超图理论设计一种物联网用户-设备交互的表示模型并配以对应的表示矩阵,进而将物联网中的资源发现问题转换为推荐问题,并将该问题转换成基于矩阵分解的相关程度预测问题,即一种基于矩阵分解的单目标优化问题,并利用交替最小二乘法来求解。最后利用开源项目 KaaProject^[24] 搭建物联网资源管理平台,并对 LFM-ALS 算法进行测试,实验结果表明,该算法相比传统推荐系统中基于物品的协同过滤算法来说,可有效降低预测误差(RMSE/MAE),如何实现算法中迭代次数 N 和隐含特征个数 K 的自动选取是下一步工作的重心。

参考文献:

- [1] 魏强, 金芝, 许焱. 基于概率主题模型的物联网服务发现[J]. 软件学报, 2014, 25(8): 1640-1658.
WEI Qiang, JING Zhi, XU Yan. Service discovery for Internet of things based on probabilistic topic mode[J]. Journal of Software, 2014, 25(8): 1640-1658.
- [2] International Telecommunication Union. ITU Internet reports 2005: The internet of things[R]. [S.l.]: ITU, 2005.
- [3] 高云全, 李小勇, 方滨兴. 物联网搜索技术综述[J]. 通信学报, 2015, 36(12): 57-76.
GAO Yunquan, LI Xiaoyong, FANG Binxing. Survey on the search of internet of things[J]. Journal on Communications, 2015, 36(12): 57-76.
- [4] YE H K H, SU C, HSU C L, et al. Transparent authentication scheme with adaptive biometric features for IoT networks[C]// Proceedings of Global Conference on 2016 IEEE Consumer Electronics. [S.l.]: IEEE, 2016: 1-2.
- [5] LINDEN G, SMITH B, YORK J. Amazon.com recommendations: Item-to-item collaborative filtering[J]. IEEE Internet Computing, 2003, 7(1): 76-80.
- [6] CAO Langcai, LI Zhihui, LIU Yuanfang. Research of text clustering based on improved VSM by TF under the framework of Mahout[C]//Proceedings of 2017 29th Chinese Control and Decision Conference (CCDC). Chongqing, China: [s.n.], 2017: 6597-6600.
- [7] TEIXEIRA T, HACHEM S, ISSARNY V, et al. Service oriented middleware for the internet of things: A perspective[C]// Proceedings of European Conference on Towards a Service-Based Internet. [S.l.]: Springer-Verlag, 2011: 220-229.
- [8] KANSAL A, NATH S, LIU J, et al. SenseWeb: An infrastructure for shared sensing[J]. IEEE Multimedia, 2007, 14(4): 8-13.
- [9] TAN C C, SHENG B, WANG H, et al. Microsearch: When search engines meet small devices[M]. [S.l.]: Springer Berlin Heidelberg, 2008: 93-110.
- [10] WANG H, TAN C C, LI Q. Snoogle: A search engine for pervasive environments[J]. IEEE Transactions on Parallel & Distributed Systems, 2010, 21(8): 1188-1202.
- [11] PERERA C, ZASLAVSKY A, CHRISTEN P, et al. Connecting mobile things to global sensor network middleware using system-generated wrappers[C]//Proceedings of Eleventh Acm International Workshop on Data Engineering for Wireless & Mobile Access. [S.l.]: ACM, 2012.
- [12] BENDADOUCHE R, ROUSSEY C, SOUSA G D, et al. Extension of the semantic sensor network ontology for wireless sensor networks: The stimulus-WSNnode-communication pattern[C]//Proceedings of International Conference on Semantic Sensor Networks. [S.l.]: CEUR-WS, 2012.
- [13] BIZER C, VIDAL M E, WEISS M. Resource description framework[J]. Serials Review, 2009, 27(1): 58-61.
- [14] OSTERMAIER B, ROMER K, MATTERN F, et al. A real-time search engine for the web of things[J]. Internet of Things, 2010, 9(2): 1-8.
- [15] YAO L, SHENG Q Z, NGU A H H, et al. Keeping you in the loop: Enabling web-based things management in the internet of things[C]//Proceedings of ACM International Conference on Conference on Information & Knowledge Management. [S.l.]: ACM, 2014.
- [16] FORESTIERO A. Multi-agent recommendation system in internet of things[C]//Proceedings of IEEE/ACM International Symposium on Cluster, Cloud and Grid Computing. [S.l.]: IEEE, 2017: 772-775.

- [17] YAO L, SHENG Q Z, NGU A H H, et al. Things of interest recommendation by leveraging heterogeneous relations in the internet of things[J]. ACM Transactions on Internet Technology, 2016, 16(2): 1-25.
- [18] WANG W, QIAN Y, TANG Y Y. Hypergraph-regularized sparse NMF for hyperspectral unmixing[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(2): 681-694.
- [19] BU J, TAN S, CHEN C, et al. Music recommendation by unified hypergraph: Combining social media information and music content[C]//Proceedings of ACM International Conference on Multimedia. [S.l.]: ACM, 2010: 391-400.
- [20] SUN L, JI S, YE J. Hypergraph spectral learning for multi-label classification[C]//Proceedings of ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Las Vegas: DBLP, 2008: 668-676.
- [21] LIU W, WANG B, WANG D. Improved latent factor model in movie recommendation system[C]//Proceedings of 2018 International Conference on Intelligent Autonomous Systems (ICoIAS). Singapore: [s.n.], 2018: 101-104.
- [22] AUNG T H, JIAMTHAPTHAKSIN R. Alternating least squares with incremental learning bias[C]//Proceedings of International Joint Conference on Computer Science and Software Engineering. [S.l.]: IEEE, 2015: 297-302.
- [23] ZACHARIAH D, SUNDIN M, JANSSON M, et al. Alternating least-squares for low-rank matrix reconstruction[J]. IEEE Signal Processing Letters, 2012, 19(4): 231-234.
- [24] Kaa IoT Platform. Kaa enterprise documentation[EB/OL]. [2022-04-12]. <https://kaaproject.github.io/kaa/docs/v0.10.0/Welcome/>.
- [25] YAO L, SHENG Q Z, NGU A H H, et al. Things of interest recommendation by leveraging heterogeneous relations in the internet of things[J]. ACM Transactions on Internet Technology, 2016, 16(2): 1-25.
- [26] SHEHADEH K S, PADMAN R. Stochastic optimization approaches for elective surgery scheduling with downstream capacity constraints: Models, challenges, and opportunities[J]. Computers & Operations Research, 2022, 137: 105523.
- [27] GÁBOR T, TIKK D. Major components of the gravity recommendation system[J]. ACM Sigkdd Explorations Newsletter, 2007, 9(2): 80-83.

作者简介:



单涛(1986-),男,博士研究生,研究方向:医疗大数据、医疗人工智能等, E-mail: nanjingtaotao@126.com。



钱琪杰(1997-),男,博士研究生,研究方向:物联网、人工智能等, E-mail: 1243440770@qq.com。



景慎旗(1983-),男,博士,研究方向:医疗大数据、图书情报学等, E-mail: jingshenqi@jsph.org.cn。



叶继元(1956-),男,教授,研究方向:图书情报学、医疗评价等, E-mail: yejiyuan@nju.edu.cn。



郭永安(1981-),通信作者,男,教授,研究方向:物联网、未来网络、边缘计算、人工智能等, E-mail: guo@njupt.edu.cn。



刘云(1967-),女,教授,研究方向:医院管理、医疗信息化等, E-mail: liuyun@njmu.edu.cn。

(编辑:夏道家)